
FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

**REDES NEURAIIS CONVOLUCIONAIS PARA APRENDIZAGEM DE
MOVIMENTOS DO JIU-JITSU BRASILEIRO**

**CONVOLUTIONAL NEURAL NETWORKS FOR MOVEMENT
LEARNING IN BRAZILIAN JIU-JITSU**

João Pedro de Souza*
Eliane Vendramini de Oliveira**

Resumo

A Inteligência Artificial está amplamente presente no cotidiano, influenciando a realização de diversas atividades. No entanto, no contexto do Jiu-Jitsu Brasileiro, a aplicação dessa tecnologia ainda é pouco explorada, configurando um campo promissor para pesquisas e inovações. Nesse sentido, este trabalho propõe a utilização de Redes Neurais Convolucionais (CNNs) para a tarefa de classificação de imagens no cenário dessa arte marcial. O classificador desenvolvido é capaz de distinguir dois movimentos distintos: pegada pelas costas e montada. Para isso, foi utilizada uma base de dados proveniente da plataforma Roboflow, e adotou-se a arquitetura de rede neural ResNet-50. Como resultado, o modelo alcançou uma acurácia de classificação de 99,74%, sendo considerado um desempenho altamente satisfatório para a tarefa proposta.

Palavras-chave: Inteligência Artificial, Jiu-Jitsu Brasileiro, Rede Neurais Convolucionais, Classificação de Imagens, ResNet-50.

Abstract

Artificial intelligence is widely present in everyday life, influencing the performance of various activities. However, in the context of Brazilian Jiu-Jitsu, the application of this technology is still little explored, representing a promising field for research and innovation. In this sense, this work proposes the use of Convolutional Neural Networks (CNNs) for the task of image classification in the context of this martial art. The developed classification is capable of distinguishing two distinct movements: back control and mount. For this, a database from the Roboflow platform was used, and the ResNet-50 neural network architecture was developed. As a result, the model achieved a classification accuracy of 99.74%, considered a highly superior performance for the proposed task.

Keywords: Artificial Intelligence, Brazilian Jiu-Jitsu, Convolutional Neural Networks, Image Classification, ResNet-50.

* Aluno do curso de Análise e Desenvolvimento de Sistemas em 2026 da Faculdade de Tecnologia de Presidente Prudente. E-mail: joaopedrodesouza8@gmail.com.

** Professora do curso de Análise e Desenvolvimento de Sistemas em 2026 da Faculdade de Tecnologia de Presidente Prudente e Orientadora da pesquisa. E-mail: eliane.oliveira02@cps.sp.gov.br.

FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

1. INTRODUÇÃO

A Inteligência Artificial é considerada uma das tecnologias mais transformadoras da atualidade com potencial de impactar diversas áreas, como saúde, educação, ciência e esporte.

Com base nessas reflexões, surge a seguinte questão de pesquisa: É possível alcançar ganhos com a aplicação da Inteligência Artificial no Jiu-Jitsu Brasileiro?

Tal questionamento se justifica pelo fato de que a aplicação da Inteligência Artificial no esporte tem sido amplamente utilizada como ferramenta estratégica para a obtenção de vantagens competitivas, contribuindo para a análise de desempenho, otimização de treinamentos e apoio à tomada de decisões. Além disso, em modalidades de combate, como o Jiu-Jitsu Brasileiro, a elevada complexidade visual das posições e transições de movimentos representa um cenário promissor para aplicações de sistemas inteligentes. Dessa maneira, considerando que o Jiu-Jitsu Brasileiro também constitui uma modalidade esportiva, é possível pressupor que essa prática possa igualmente se beneficiar da aplicação de técnicas de Inteligência Artificial, possibilitando melhorias no desempenho e no acompanhamento técnico de atletas.

A presente pesquisa tem como objetivo geral utilizar Redes Neurais Convolucionais para a distinção entre dois movimentos do Jiu-Jitsu Brasileiro: pegada pelas costas e montada. Além do desenvolvimento técnico, a iniciativa busca apresentar, de maneira objetiva e acessível, o fluxo típico de funcionamento de sistemas baseados em Aprendizagem de Máquina aplicados a tarefas de classificação. Também tem como objetivo avaliar o potencial dessas tecnologias como base para a análise e interpretação de movimentos no Jiu-Jitsu Brasileiro, bem como servir como uma demonstração inicial e comprobatória da aplicabilidade da Inteligência Artificial nesse contexto.

Já quanto aos objetivos específicos, destacam-se:

- a) Identificar os benefícios da classificação de imagens no Jiu-Jitsu Brasileiro;
- b) Realizar o treinamento e aplicação de uma Rede Neural Artificial para a distinção de movimentos do Jiu-Jitsu Brasileiro.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Redes Neurais Convolucionais (CNN)

As Redes Neurais Convolucionais (CNNs – *Convolutional Neural Networks*) são uma arquitetura de Aprendizado Profundo desenvolvida especialmente para lidar com dados que

FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

possuem estrutura em grade, como imagens, vídeos e até sinais em formato bidimensional. Essas redes “se diferenciam dos algoritmos clássicos de aprendizado de máquina, como SVMs e árvores de decisão, por sua capacidade de extrair recursos de forma autônoma em grande escala, evitando a necessidade de engenharia manual de recursos e, assim, aumentando a eficiência” (DATACAMP, 2024).


As CNNs são compostas por três principais camadas: camada convolucional, camada de agrupamento e camada totalmente conectada.

Cada camada é responsável por uma tarefa específica conforme os dados se aprofundam na Rede Neural Convolucional. A seguir, é descrito cada uma das tarefas desempenhadas por cada camada:

- Camada convolucional – Considerada essencial, uma vez que “é o principal componente de uma CNN e onde ocorre a maior parte dos cálculos” (IBM, s.d.). Sua principal função é extrair características relevantes da imagem por meio da aplicação de filtros (*kernels*), que percorrem a imagem realizando operações matemáticas sobre pequenas regiões. Como resultado, são gerados mapas de características (*feature maps*), capazes de representar padrões importantes, como bordas, texturas e formas.
- Camada de agrupamento – Percorre todo o mapa de características reduzindo sua dimensionalidade e preservando características mais relevantes. O agrupamento é feito por operações como: *max pooling* ou *average pooling*.
- Camada totalmente conectada – “Esta camada desempenha a função de classificação com base nas características extraídas através das camadas anteriores e dos seus diferentes filtros” (SOFTTEK, 2021).

A Figura 1 apresenta o fluxo completo de funcionamento de uma Rede Neural Convolucional, desde a imagem de entrada até a etapa final de classificação, na qual são obtidas as probabilidades associadas a cada classe.

Figura 1 – Fluxo de funcionamento das CNNs



Fonte: VISO.AI (2021)

FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

2.2 ResNet-50

O aumento da profundidade de uma Rede Neural, por si só, não garante a otimização do processo de treinamento, tampouco assegura alto desempenho nas tarefas propostas. Pelo contrário, redes muito profundas podem enfrentar dificuldades como degradação do desempenho e problemas de propagação do gradiente, o que compromete a eficiência do aprendizado. Diante desse cenário, as Redes Residuais surgiram como uma alternativa promissora, permitindo o treinamento mais eficaz de arquiteturas profundas por meio do uso de conexões de atalho, conforme evidenciado por Kundu (2023), “Essas conexões residuais permitem que a rede aprenda arquiteturas muito mais profundas do que era possível anteriormente, sem sofrer com o problema do desaparecimento dos gradientes”.

Os blocos residuais são componentes essenciais das Redes Residuais, pois permitem que a rede aprenda apenas ajustes sobre a entrada, facilitando o treinamento de arquiteturas profundas. “Na prática, cada bloco residual no ResNet-50 consiste em uma série de camadas convolucionais seguidas por uma conexão direta (ou ‘conexão de salto’) que adiciona a entrada inicial à saída dessas camadas” (INNOVATIANA, 2024).

De maneira simples, em um bloco residual a entrada x passa por algumas camadas convolucionais que geram uma saída $F(x)$. Em seguida, a Rede Residual utiliza uma conexão de atalho que copia a entrada original x e soma com essa saída transformada. Assim, a saída final do bloco é $y = F(x) + x$.

Nesse contexto, a ResNet-50 destaca-se como uma arquitetura de Rede Neural Convolucional amplamente utilizada, pertencente à família ResNet, sendo reconhecida por sua capacidade de extrair características complexas e alcançar bons resultados em tarefas de classificação de imagem.

Outro aspecto interessante do modelo ResNet-50 é a sua capacidade de suportar a aprendizagem por transferência. Isto significa que o modelo, originalmente treinado num grande conjunto de dados como o ImageNet para classificação de imagens, pode ser adaptado a novas tarefas com muito menos dados. Em vez de começar do zero, a maioria das camadas do modelo são reutilizadas, e apenas a camada de classificação final é substituída e retreinada para a nova tarefa. Isso economiza tempo e é especialmente útil quando os dados rotulados são limitados (ULTRALYTICS, 2025).

2.3 Jiu-Jitsu Brasileiro

O Jiu-Jitsu Brasileiro é uma arte marcial e esporte de combate que se destaca pelo foco em técnicas de luta no solo. Seu principal objetivo é a utilização “de golpes de alavancas,

FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

torções e pressões para levar um oponente ao chão e dominá-lo. Literalmente, jū em japonês significa ‘suavidade’, ‘brandura’, e jutsu, ‘arte’, ‘técnica’. Daí seu sinônimo literal, ‘arte suave’” (GRACIEMAG, s.d.).

O Jiu-Jitsu Brasileiro “surtiu no Japão Feudal, em um contexto em que os samurais precisam se defender mesmo quando estavam sem armas” (ATLETIS, 2025). Porém, a arte marcial ganhou notoriedade no mundo a partir principalmente pela família Gracie ao longo do século XX, que ajudou a popularizar o estilo e aperfeiçoar suas técnicas.

Nas competições, os atletas podem vencer por pontos, que são obtidos por posições de controle e domínio, ou por finalização, quando o adversário desiste devido a uma técnica bem aplicada.

O Jiu-Jitsu Brasileiro possui um sistema de pontuação utilizado em competições para determinar o vencedor quando não ocorre finalização. Esse sistema tem como objetivo valorizar ações que proporcionam vantagem técnica e domínio posicional sobre o adversário. Entre as pontuações mais comuns estão a queda (2 pontos), a raspagem (2 pontos), a passagem de guarda (3 pontos), a montada (4 pontos) e a pegada pelas costas (4 pontos).

Atualmente, o Jiu-Jitsu Brasileiro é amplamente praticado em academias e competições ao redor do mundo, sendo considerado uma modalidade importante tanto no cenário esportivo quanto no desenvolvimento físico e mental de seus praticantes.

3. MÉTODOS

3.1 Introdução do projeto de classificação binária de imagens aplicada ao Jiu-Jitsu

Este projeto tem como objetivo desenvolver uma solução de classificação de imagens utilizando Redes Neurais Convolucionais, aplicada ao contexto do Jiu-Jitsu Brasileiro. Ao final do projeto, espera-se obter um classificador capaz de distinguir automaticamente entre duas posições fundamentais da modalidade: montada e pegada pelas costas.

3.2 Coleta dos dados

A obtenção das imagens que compõem o *dataset* foi realizada a partir da plataforma Roboflow, por meio do conjunto de dados “*Grappling Set*”, disponibilizado por um usuário da plataforma.

O *dataset* disponibilizou um conjunto de dados com quantidade significativa de imagens, sendo selecionado por conter classes diretamente relacionadas às posições de interesse

FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

neste trabalho.

Apesar do volume adequado de dados, observou-se uma menor diversidade de cenários, variações visuais e contexto das imagens. Essa característica pode impactar a capacidade de generalização do modelo em ambientes distintos. Ainda assim, o conjunto mostrou-se suficiente para o treinamento e validação do objetivo proposto.

3.3 Análise exploratória inicial dos dados


Ressalta-se que as imagens provenientes da plataforma Roboflow já estavam previamente anotadas de acordo com o formato YOLO (*You Only Look Once*), o que eliminou a necessidade de etapas adicionais de rotulação manual, contribuindo para a filtragem e limpeza do *dataset*.

Após a obtenção das imagens originadas do Roboflow, destacam-se as seguintes características:

- Quantidade total de imagens: 6.028
- Quantidade total de classes: 22

Com o objetivo de evidenciar essa distribuição, apresenta-se a seguir na Figura 2 um gráfico contendo a distribuição das classes do *dataset*.

Figura 2 – Distribuição de imagem por classe



Fonte: Elaborado pelo autor a partir de dados do *dataset Grappling Set* (2026)

Cabe destacar que este conjunto corresponde à versão inicial dos dados, não representando o subconjunto final utilizado neste trabalho.

3.4 Filtragem dos dados

O processo de filtragem do *dataset* foi realizado com o objetivo de selecionar apenas as

FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

imagens correspondentes às classes de interesse. A filtragem foi guiada pelas anotações no formato YOLO, onde para cada arquivo de anotação, foi feita a leitura das classes presentes, permitindo identificar se a imagem associada continha pelo menos uma das classes de interesse.

A seguir estão discriminadas as classes de interesse:

- Classes 1 e 2 ('*back1*' e '*back2*'): correspondem a imagens de pegada pelas costas, representando situações em que um atleta está posicionando-se nas costas do oponente;
- Classes 11 e 12 ('*mount1*' e '*mount2*'): correspondem a imagens de montada, representando situações em que um atleta está montado sobre o adversário.

A partir desse critério, o *dataset* passou pelas seguintes modificações:

- 1º) Preservação das imagens relevantes: imagens que possuíam ao menos uma anotação pertencente às classes 1, 2, 11 ou 12 foram mantidas no *dataset*;
- 2º) Remoção de imagens irrelevantes: imagens cujas anotações não continham nenhuma das classes de interesse foram descartadas;
- 3º) Criação de dois subconjuntos específicos a partir do *dataset* filtrado. O primeiro subconjunto contém apenas imagens das classes 1 e 2. O segundo subconjunto é composto exclusivamente por imagens e anotações das classes 11 e 12.

No final do processo de filtragem e limpeza, foi possível reduzir o *dataset* inicial de 6028 imagens para 1294 imagens, mantendo apenas as duas classes de interesse: pegada pelas costas e montada. Desse total, 680 imagens correspondem à classe pegada pelas costas e 614 imagens à classe montada.

3.5 Divisão do dataset em treinamento e teste

O *dataset* foi dividido em dois subconjuntos distintos, treinamento e teste. Para isso, 70% das imagens foram destinadas ao conjunto de treinamento, enquanto os 30% restantes foram reservados ao conjunto de teste

FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

A divisão foi realizada com apoio da função *train_test_split*, disponível na biblioteca Scikit-learn (`sklearn.model_selection`).

No conjunto destinado ao treinamento, foram utilizadas 476 imagens da classe 0 (Pegada pelas costas) e 429 imagens da classe 1 (Montada). Já no conjunto de teste, foram utilizadas 204 imagens da classe 0 (Pegada pelas costas) e 185 imagens da classe 1 (Montada).

3.6 Treinamento

O processo de treinamento do classificador foi implementado em *Python* no ambiente de desenvolvimento Jupyter Notebook. Para implementação do classificador e das rotinas de aprendizado, foi utilizada principalmente a biblioteca TensorFlow/Keras, responsável pela configuração e treinamento da Rede Neural.

A arquitetura de Rede Neural Profunda adotada foi baseada na ResNet-50 pré-treinada no conjunto ImageNet, utilizando a abordagem de transferência de aprendizagem na modalidade de extração de características. Nesse processo, as camadas de extração de características da ResNet50 foram congeladas, mantendo seus pesos originais e impedindo sua atualização durante o treinamento. Dessa maneira, apenas o classificador final foi treinado, aproveitando as representações previamente aprendidas pela rede em tarefas de reconhecimento visual.

Foram realizados os seguintes ajustes para adaptar o modelo ao problema de classificação binária:

- 1º. Adicionada uma camada *GlobalAveragePooling2D*, responsável por reduzir o mapa de características extraído pela ResNet50;

Em seguida foram implementadas duas camadas densas:

- 2º. A primeira camada densa, com 128 neurônios e função de ativação ReLU, foi utilizada como camada intermediária para aprendizado de padrões relevantes;
- 3º. A segunda camada densa de saída com 1 neurônio e função de ativação sigmoid, responsável por gerar a probabilidade associada à classe prevista.

Essa configuração é compatível com a função de perda *Binary Crossentropy*, que

FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

calcula o erro comparando a probabilidade estimada pelo modelo com o rótulo real da classe (0 ou 1).

O treinamento do modelo foi configurado com 10 épocas (*epochs*), de modo que a rede percorresse o conjunto de treinamento por dez ciclos completos. Além disso, foi definido um tamanho de lote igual a 32, ou seja, a cada iteração o modelo processou 32 imagens simultaneamente para atualização dos pesos das camadas treináveis do classificador final. Em cada época foram realizados 29 passos (*steps*), correspondentes à quantidade de *batches* necessários para processar todo o conjunto de treinamento, totalizando 29 iterações por época.

4 RESULTADOS E DISCUSSÃO

É possível observar na Figura 3 uma melhora rápida e consistente nos resultados. Na primeira época, a acurácia de treinamento foi de aproximadamente 92,93%, porém a partir da segunda época o modelo já atingiu 100% de acurácia, mantendo esse valor até o final do treinamento. Isso indica que o modelo aprendeu muito rapidamente a classificar corretamente os dados utilizados no treinamento.

Figura 3 – Log do treinamento do modelo ResNet50

```
Epoch 1/10
29/29 ————— 485s 14s/step - accuracy: 0.9293 - loss: 0.1616 - val_accuracy: 0.9949 - val_loss: 0.0193
Epoch 2/10
29/29 ————— 353s 11s/step - accuracy: 1.0000 - loss: 0.0037 - val_accuracy: 0.9949 - val_loss: 0.0156
Epoch 3/10
29/29 ————— 322s 11s/step - accuracy: 1.0000 - loss: 0.0017 - val_accuracy: 0.9974 - val_loss: 0.0129
Epoch 4/10
29/29 ————— 292s 10s/step - accuracy: 1.0000 - loss: 8.8620e-04 - val_accuracy: 0.9949 - val_loss: 0.0124
Epoch 5/10
29/29 ————— 403s 13s/step - accuracy: 1.0000 - loss: 6.9193e-04 - val_accuracy: 0.9974 - val_loss: 0.0118
Epoch 6/10
29/29 ————— 340s 12s/step - accuracy: 1.0000 - loss: 5.6510e-04 - val_accuracy: 0.9974 - val_loss: 0.0117
Epoch 7/10
29/29 ————— 346s 10s/step - accuracy: 1.0000 - loss: 4.7228e-04 - val_accuracy: 0.9974 - val_loss: 0.0114
Epoch 8/10
29/29 ————— 289s 9s/step - accuracy: 1.0000 - loss: 3.9480e-04 - val_accuracy: 0.9974 - val_loss: 0.0114
Epoch 9/10
29/29 ————— 173s 6s/step - accuracy: 1.0000 - loss: 3.3868e-04 - val_accuracy: 0.9974 - val_loss: 0.0110
Epoch 10/10
29/29 ————— 208s 7s/step - accuracy: 1.0000 - loss: 2.9192e-04 - val_accuracy: 0.9974 - val_loss: 0.0104
```

Fonte: Elaborado pelo autor (2026)

Além disso, a perda apresentou uma redução significativa ao longo das épocas. No início, o valor era 0,1616, mas caiu drasticamente já nas primeiras épocas, chegando a valores muito baixos ao final do treinamento (0,00029). Isso mostra que o modelo foi se ajustando cada vez melhor aos dados de treinamento, cometendo menos erros.

O modelo foi avaliado utilizando o conjunto de teste. Os resultados obtidos estão apresentados na Figura 4.

FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

Figura 4 – Log das métricas obtidas do classificador

13/13 ————— 59s 4s/step


----- MÉTRICAS NO CONJUNTO DE TESTE -----

Métrica	Valor
CA	99.74%
AUC	0.9999
F1	0.9973
Precision	0.9946
Recall	1.0000

Fonte: Elaborado pelo autor (2026)

A matriz de confusão foi utilizada como ferramenta complementar para avaliar o desempenho do classificador no conjunto de teste, permitindo identificar com maior clareza como o modelo se comporta em cada classe, conforme apresentada na Figura 20.

Figura 6 – Matriz de confusão



Fonte: Elaborado pelo autor (2026)

Os resultados obtidos pelo classificador demonstraram alto desempenho, alcançando uma acurácia de 99,74%. Esse valor pode ser considerado elevado quando comparado a estudos semelhantes, nos quais resultados em torno de 88% já são descritos como relevantes para tarefas de reconhecimento de objetos utilizando redes neurais convolucionais (MIYAZAKI, 2017). Diante dessa perspectiva, o desempenho obtido neste trabalho indica elevada capacidade de classificação das posições analisadas.

Em contrapartida, conforme mencionado anteriormente, embora o *dataset* utilizado no treinamento apresentasse uma quantidade de imagens satisfatória para um escopo simples, a homogeneidade das imagens utilizadas indica fortemente que o classificador esteve sujeito a *overfitting*. Essa hipótese é reforçada pelo fato de que, ao ser exposto a imagens que não

FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

pertenciam nem ao conjunto de treino nem ao conjunto de teste, o modelo não apresentou um desempenho convincente. Observou-se que, devido à presença de outros elementos, como variações de cenário, vestuário e até mesmo de ângulos, na maioria das vezes o classificador não realizou a classificação esperada. Logo, conclui-se que o modelo possivelmente não aprendeu de fato o movimento em questão, mas sim outras características específicas presentes nas imagens utilizadas durante o treinamento.

5 CONCLUSÃO

É possível concluir que ferramentas baseadas em Aprendizagem de Máquina possuem grande potencial para contribuir com o auxílio à arbitragem, por meio da identificação automática de posições e situações de combate; a prevenção de lesões, a partir da análise de padrões de movimento e sobrecarga física; e o refinamento técnico, permitindo que atletas e treinadores obtenham *feedbacks* mais precisos sobre execuções e estratégias. Portanto, conclui-se que o Jiu-Jitsu Brasileiro pode ser beneficiados pelo uso de tecnologias baseadas em Inteligência Artificial, como o classificador desenvolvido.

Como considerações finais, destaca-se que, embora os resultados obtidos neste trabalho tenham sido satisfatórios dentro do escopo proposto, há diversas oportunidades de aprimoramento que podem ser exploradas em estudos futuros, especialmente no que diz respeito à ampliação da diversidade do *dataset* e ao aumento da capacidade de generalização do classificador em diferentes cenários.

Outra sugestão consiste na aplicação de técnicas de *data augmentation* no *dataset* existente. Essa estratégia não apenas amplia o conjunto de treinamento, como também contribui para reduzir problemas como *overfitting*, promovendo uma melhor capacidade de generalização do modelo diante de variações do mundo real.

As propostas apresentadas configuram caminhos promissores para trabalhos futuros, com potencial de elevar a qualidade do *dataset* e aprimorar significativamente a performance do modelo, sobretudo em termos de robustez e generalização.

Agradecimentos

Agradeço à FATEC – Presidente Prudente pela oportunidade de aprendizado e pela estrutura oferecida ao longo da graduação, contribuindo diretamente para minha formação acadêmica e profissional.

Agradeço, de forma especial, à professora Eliane Vendramini de Oliveira, pela tutoria,

FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

orientação e apoio durante o desenvolvimento deste trabalho, sempre demonstrando dedicação, comprometimento e disponibilidade para auxiliar em todas as etapas.

REFERÊNCIAS

ATLETIS. **Guia completo sobre jiu-jítsu: história, regras e atletas.** Por Redação, 08 maio 2025 (atualizado em 15 maio 2025). Disponível em: <https://www.atletis.com.br/jiu-jitsu>. Acesso em: 29 abr. 2026.

DATA CAMP. **Introdução às Convolutional Neural Networks (CNNs).** DataCamp, 24 abr. 2024. Disponível em: <https://www.datacamp.com/pt/tutorial/introduction-to-convolutional-neural-networks-cnns/>. Acesso em: 19 abr. 2026.

GRACIEMAG. **A história do Jiu-Jitsu.** Disponível em: <https://www.graciemag.com/historia-do-jiu-jitsu/>. Acesso em: 29 abr. 2026.

IBM BRASIL. **O que são redes neurais convolucionais (CNN).** IBM Think. Disponível em: <https://www.ibm.com/br-pt/think/topics/convolutional-neural-networks>. Acesso em: 8 maio 2026.

INNOVATIANA. **ResNet-50: important architecture for modern AI.** Innovatiana, 17 ago. 2024. Disponível em: <https://www.innovatiana.com/en/post/discover-resnet-50>. Acesso em: 8 maio 2026.

KUNDU, Nitish. **Exploring ResNet50: an in-depth look at the model architecture and code implementation.** Medium, 23 jan. 2023. Disponível em: <https://medium.com/@nitishkundu1993/exploring-resnet50-an-in-depth-look-at-the-model-architecture-and-code-implementation-d8d8fa67e46f>. Acesso em: 8 maio 2026.

MIYAZAKI, C. K. **Redes neurais convolucionais para aprendizagem e reconhecimento de objetos 3D.** 2017. 56 f. Monografia (Trabalho de Conclusão de Curso) — Escola de Engenharia de... [detalhar nome da escola, universidade e cidade se necessário], Universidade de São Paulo (USP), 2017.

SOFTTEK. **As CNNs melhoram a análise de imagem.** Softtek Blog, nov. 16 2021. Disponível em: <https://blog.softtek.com/pt/as-cnns-melhoram-a-analise-de-imagem>. Acesso em: 8 maio 2026.

ULTRALYTICS. **O que é ResNet-50 e qual é a sua relevância em visão computacional?** Ultralytics, 27 maio 2025. Disponível em: <https://www.ultralytics.com/pt/blog/what-is-resnet-50-and-what-is-its-relevance-in-computer-vision>. Acesso em: 25 abr. 2026.

VISO.AI. **Deep Neural Networks: Types & Basics Explained.** Viso.ai, 8 abr. 2021. Disponível em: <https://viso.ai/deep-learning/deep-neural-network-three-popular-types/>. Acesso em: 21 abr. 2026.